Universidade Católica de Brasília
Pró-Reitoria de Pós-Graduação e Pesquisa
Mestrado em Gestão do Conhecimento e da Tecnologia da Informação

Aplicação de Redes Neurais para verificação das tendências de preço de ações utilizando a Teoria de Dow

Alunos:
Fúlvio Longhi
Ricardo Fernandes da S. Neiva

Orientadores:
Edílson Ferneda
Rogério Alvarenga

Brasília, DF - Junho de 2006

Aplicação de Redes Neurais para verificação das tendências de preço de ações utilizando a Teoria de Dow.

Edílson Ferneda, Fúlvio Longhi, Ricardo Neiva, Rogério Alvarenga

Resumo. *Devido a recente popularização dos home-brokers, o volume de aplicações em ações negociadas na bolsa de valores tem aumentado entre o pequeno e o médio investidor, os quais não detêm conhecimento suficiente sobre teorias e estratégias de investimento. Este artigo tem como propósito avaliar a implementação de uma rede neural para verificação das tendências de ações negociadas na bolsa de valores, visando predizer se a tendência que está se formando é verdadeira ou falsa. Utilizou-se no trabalho aspectos da Teoria de Dow como base para a modelagem de dados, juntamente com a metodologia CRISP-DM como processo de desenvolvimento do trabalho, e rede neural artificial multi layer perceptron com feed-forward e back-propagation para o processamento e a avaliação das tendências. Como resultado, foi verificada a porcentagem de acertos da rede após o treinamento, bem como os pontos a serem melhorados no processo.*

1 Introdução

Com o advento da Internet, vários setores têm vislumbrado ganhos consideráveis, marcados pela elevação no volume das transações e pelas facilidades na realização das mesmas. Não obstante, o mercado financeiro tem sido um setor caracterizado por um aumento substancial referente ao número e ao ganho real das facilidades em suas transações, neste novo contexto, surgiram os home-brokers, que são as transações realizadas via terminais de computadores em qualquer lugar do mundo. Sendo assim, o volume de aplicações em ações negociadas na Bolsa de Valores tem sido marcado pelo aumento entre o pequeno e o médio investidor, os quais não detêm muito conhecimento sobre teorias e estratégias de investimento.

Verifica-se, quanto ao mercado financeiro, alta volatilidade onde têm-se desenvolvido muitas teorias e estudos experimentados na busca de previsão de ações e comportamentos futuros. Para SATYADAS (1994), a previsão é um fenômeno universal

utilizado em atividades cognitivas de baixo nível como visão e percepção, mas também em outras de alto nível como planejamento e inferência, bastante utilizadas na área de Economia e Finanças.

Devido à natureza dinâmica e a característica extremamente não linear dos dados econômicos restringem o uso das análises clássicas que utilizam séries temporais para previsões em Economia (FREIMAN & PAMPLONA, 2005).

Por outro lado, as redes neurais artificiais têm registrado aplicações bem sucedidas quando se exigem inferência de complexas relações não lineares entre variáveis de entrada e de saída (FREIMAN & PAMPLONA, 2005).

A principal diferença entre redes neurais e as abordagens estatísticas é que as redes neurais não estabelecem hipóteses ou suposições sobre a distribuição ou propriedades dos dados, e desta forma tendem a ser mais úteis em situações práticas. As RNA's constituem também uma abordagem inerentemente não-linear, fornecendo mais precisão quando modelando dados de padrões complexos. Existem vários tipos de redes, cada uma com diferentes objetivos, arquitetura e algoritmo de aprendizagem (SMITH & GUPTA, 2000).

Diante do exposto, este trabalho tem como propósito premente avaliar a implementação de uma rede neural para verificação das tendências de ações negociadas na bolsa de valores, visando predizer se a tendência que está se formando é verdadeira ou falsa. Utilizou-se, neste trabalho, aspectos da Teoria de Dow como base para a modelagem dos dados, juntamente com a metodologia CRISP-DM como processo de desenvolvimento, e a rede neural artificial multi layer perceptron com feed-forward e back-propagation para processamento e avaliação das tendências. Como resultado, foi verificada a porcentagem de acertos da rede após o treinamento, bem como os pontos a serem melhorados no processo.

2 Redes Neurais Artificiais

Rede Neural é uma máquina que é projetada para modelar a maneira como o cérebro realiza uma tarefa particular ou função de interesse; a rede é normalmente implementada utilizando-se componentes eletrônicos ou é simulada por programação em um computador digital (HAYKIN, 2002).

Figura 1 - Computação neural.
Fonte: Osório & Bittencourt (2000)

Uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos:

1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.
2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido (HAYKIN, 2002).

As redes neurais são formadas por neurônios que se encontram conectados. O neurônio é a parte central, onde todas as informações são processadas.

Segundo FREIMAN & PAMPLONA (2005), a teoria de RNA pode ser dividida em três tópicos básicos:

a) **Elemento processador ou neurônio artificial** - elemento básico, inspirado no neurônio biológico e constituído de três partes fundamentais: pesos sinápticos, que ponderam os valores das entradas do neurônio, regra de propagação, que define como as entradas serão combinadas no neurônio - em geral é um somatório ponderado - e a função de ativação, que determina o efeito que o resultado da regra de propagação terá sobre o nível de ativação do neurônio. A figura 2 mostra um modelo simplificado de um neurônio biológico. Na figura 3 temos o correspondente neurônio artificial.

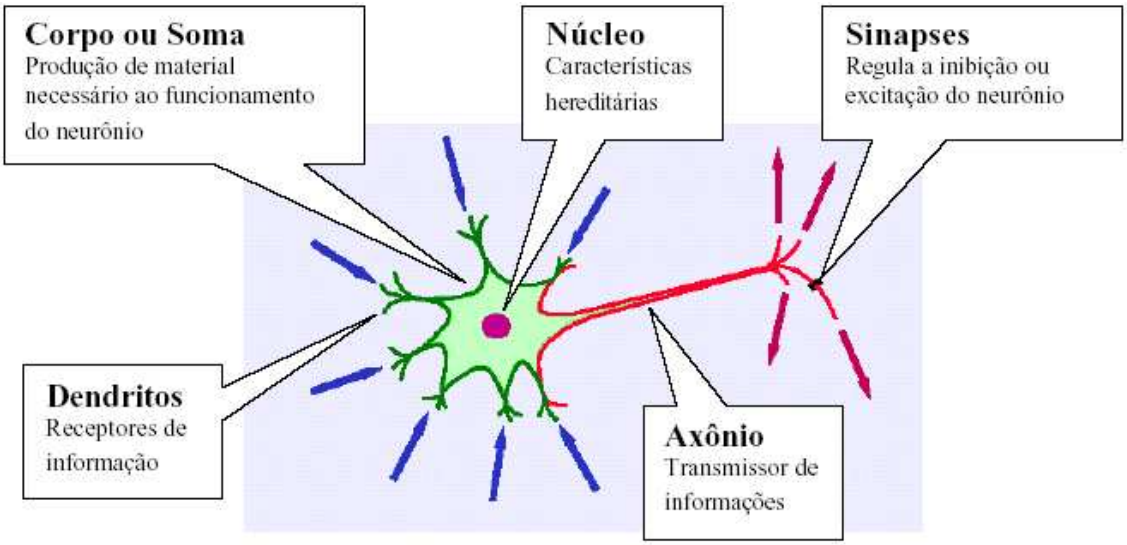

Figura 2 . Modelo simplificado de um tipo de neurônio biológico.
Fonte: Falcão (2003)

b) Topologia - modo de conexão entre os diferentes neurônios que formam a RNA. O encadeamento de vários destes neurônios formam as camadas. Em geral a rede possui três ou mais camadas de neurônios, sendo que a primeira recebe o nome de camada de entrada, a última é a camada de saída e a(s) camada(s) intermediária(s) de camada(s) escondida(s) ou oculta(s). Uma RNA com a topologia (2-4-4-1) indica que ela possui a camada de entrada com 2 elementos processadores, duas camadas intermediárias (ocultas), cada qual com 4 elementos processadores e a camada de saída com apenas 1 elemento processador. O fluxo dos dados conforme o algoritmo back-propagation ocorre em dois sentidos: para frente e para trás. A figura 4 mostra um exemplo de rede com a topologia citada.

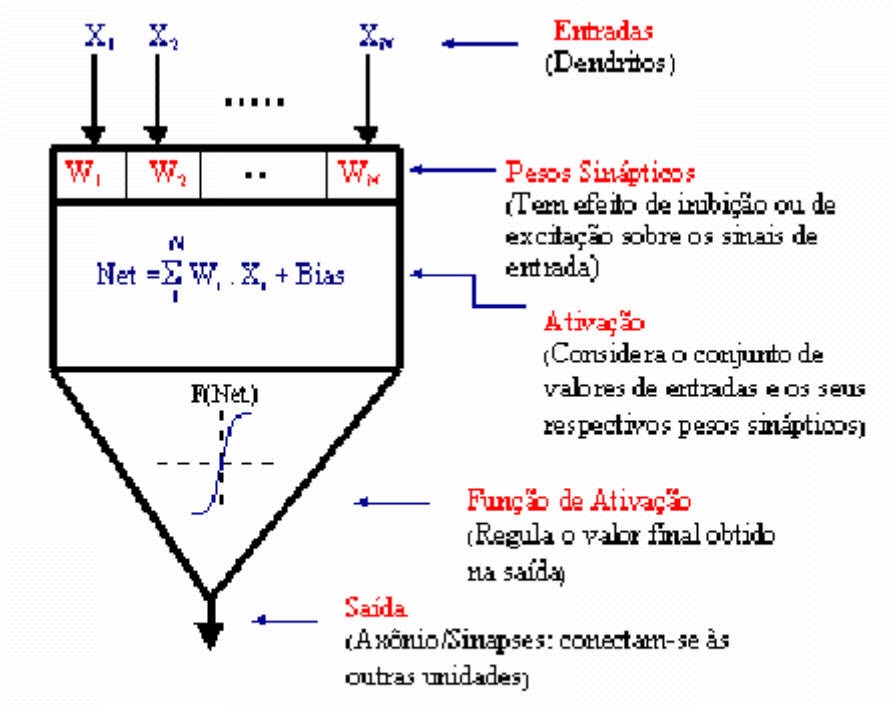

Figura 3 - Modelo de um neurônio artificial (elemento processador).
Fonte: Osório & Bittencourt (2000)

c) **Aprendizado**: processo pelo qual a RNA aprende por meio dos padrões a ela apresentados. Os procedimentos de aprendizado (ou treinamento) que levam as RNA's a aprender determinadas tarefas podem ser classificados em duas classes: treinamento supervisionado, onde a rede é alimentada por dados de entrada e seus respectivos valores de saída (alvo) e treinamento não supervisionado, que não requer valores de saída, onde a rede agrupa os valores de maior semelhança (clusters).

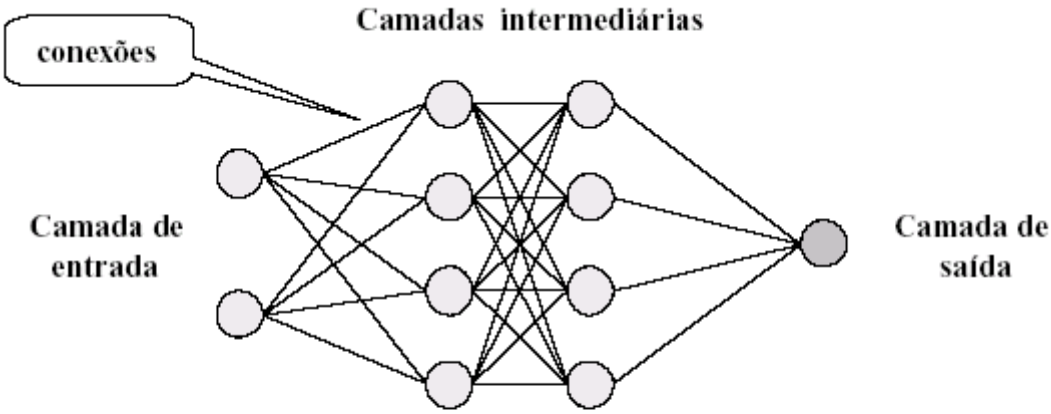

Figura 4 - Rede neural com a topologia (2-4-4-1).

2.1 Rede Neural Backpropagation

A rede neural, comumente denominada backpropagation, é uma rede neural feedforward (veja a figura abaixo), multicamada e treinada pelo algoritmo backpropagation. Segundo LAWRENCE (1997), esta rede é a mais utilizada no desenvolvimento de redes neurais para o mercado financeiro. O desenvolvimento deste algoritmo de aprendizagem foi um dos marcos mais importantes das pesquisas em redes neurais artificiais (DANDOLINI, 1997). Este trabalho foi o primeiro que possibilitou o ajuste dos pesos em redes multicamadas feedforward, abrindo caminho para a elaboração de redes neurais mais genéricas. Devido a grande popularidade do método backpropagation, seu nome é utilizado para denominar as redes que o utilizam no seu treinamento.

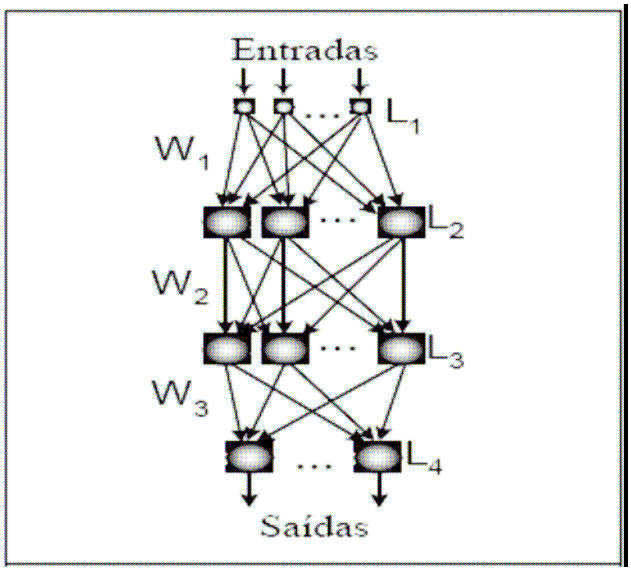

Figura 5: Rede Neural Feedforward

A atratividade do método backpropagation vem do conjunto de equações bem definidas e explícitas para correção dos pesos da rede (DANDOLINI, 1997). Este algoritmo consiste em realizar a retropropagação do erro gerado na comparação entre a saída da rede e a saída desejada com o objetivo de minimizar o erro total da saída gerada pela rede. O treinamento de uma rede através deste algoritmo envolve três etapas: a propagação dos dados da camada de entrada para a camada de saída da rede, o cálculo e a retropropagação do erro gerado pela rede, e o ajuste dos pesos (FAUSETT, 1994).

3 Metodologia CRISP-DM

CRISP-DM (CRoss-Industry Standard Process for Data Mining) é uma metodologia que fornece um roteiro para a condução de um projeto de descoberta de conhecimento em banco de dados (CRISP-DM, 2000). Ele é dividido em 6 fases, conforme pode ser observado na Figura 6:

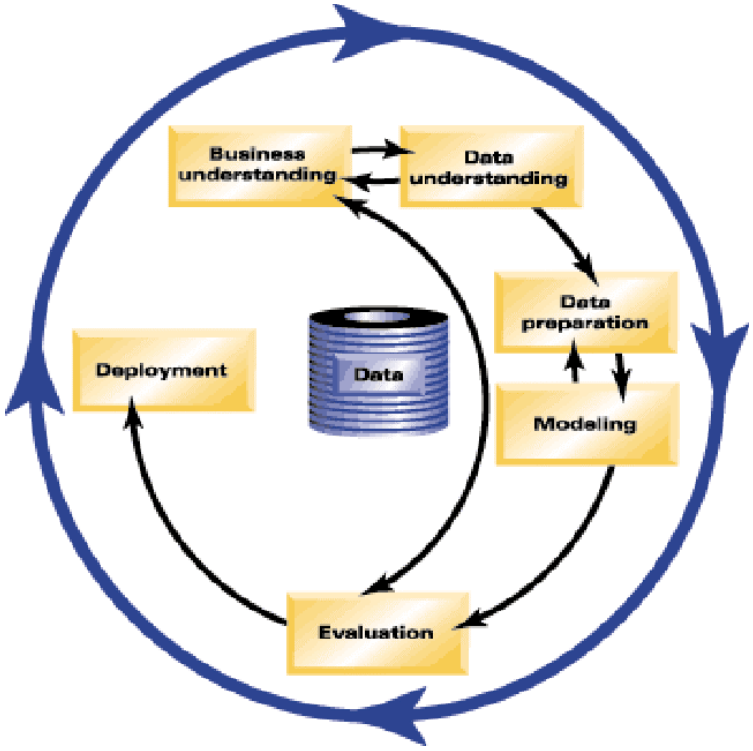

Fig. 6 - Fases da metodologia CRISP-DM

3.1 Fases do CRISP-DM

Fase 1: Entendimento do negócio

Esta fase visa identificar os objetivos e requisitos, convertê-los para uma aplicação de descoberta de conhecimento em banco de dados e então desenvolver um plano preliminar para atingir os objetivos.

Fase 2: Entendimento dos dados

Esta fase envolve a coleta, descrição, exploração e verificação da qualidade dos dados.

Fase 3: Preparação dos dados

A fase de preparação dos dados cobre todas as atividades para construção do conjunto de dados finais que serão utilizados como entrada nas ferramentas de modelagem a partir dos dados iniciais.

Fase 4: Modelagem

Nesta fase várias técnicas de modelagem são selecionadas e aplicadas, e seus parâmetros são otimizados.

Fase 5: Avaliação

O objetivo desta fase é avaliar os modelos com a visão do negócio.

Fase 6: Disponibilização

A criação e a validação do modelo permite avançarmos mais um passo, no sentido de tornar a informação gerada acessível.

4 Contextualização

4.1 Bolsa de Valores

A origem das bolsas de valores é bastante remota. Alguns escritores a localizam nos *emporium* dos gregos, outros nos *collegium mercatorum* dos romanos, ou nos *funduks* (bazares) dos palestinos (CAVALCANTE, MISUMI & RUDGE, 2005).

Não há uma definição histórica clara sobre isto. Sabe-se apenas que elas surgiram em épocas distantes, com atribuições que não as vinculam especificamente a valores mobiliários. Mas o comportamento dos mercados sintetizava o procedimento comercial que daria vida às bolsas: a negociação de viva voz, superando barreiras geográficas, lingüísticas e ideológicas (CAVALCANTE, MISUMI & RUDGE, 2005).

A palavra “bolsa”, no seu sentido comercial e financeiro, nasceu em Bruges, cidade lacustre da Bélgica, capital de Flandres, pertencente à Liga Hanseática, onde se realizavam assembléias de comerciantes na casa de um senhor chamado Van der Burse, em cuja fachada havia um escudo com três bolsas, brasão d’armas do proprietário (CAVALCANTE, MISUMI & RUDGE, 2005).

Mas, só no século XVIII estas instituições atingiram um grande desenvolvimento, quando as exigências de crédito público obrigaram os banqueiros a fracionar os empréstimos em títulos de participação. Com a expansão das sociedades por ações, permitindo grandiosos agrupamentos de capital, elas assumiram um papel preponderante na oferta e procura de capitais (OLIVEIRA, 1988).

As bolsas de valores são instituições civis sem fins lucrativos, sendo seu patrimônio representado por títulos patrimoniais que pertencem às sociedades corretoras membros (FILHO, 1995). Possui autonomia financeira, patrimonial, e administrativa, mas está sujeita a supervisão da Comissão de Valores Mobiliários e obedece às diretrizes e políticas emanadas do Conselho Monetário Nacional (CAVALCANTE, MISUMI & RUDGE, 2005).

4.1.1 A Bolsa de Valores no Brasil

Desde os mercados medievais até hoje, as bolsas de valores vêm sofrendo profundas transformações em sua estrutura. No Brasil, seu desenvolvimento está intrinsecamente ligado ao desenvolvimento da estrutura financeira do país, que se assentou basicamente sobre dois tipos de instituições: os bancos comerciais e as bolsas de valores (CAVALCANTE, MISUMI & RUDGE, 2005).

As atividades das bolsas e corretoras dos demais estados (além do então Distrito Federal) foram regulamentadas pelo Governo Federal somente em 1934, através do Decreto n° 24.275. Mas a legislação tornou-se mais afirmativa, passando a reger todas as bolsas do país, a partir do decreto-lei n° 1.344 de 1939. No entanto, mesmo depois dele, elas continuaram sendo entidades públicas com ingerência dos governos estaduais em suas administrações (CAVALCANTE, MISUMI & RUDGE, 2005).

Por intermédio das reformas que institucionalizaram o sistema financeiro nacional, iniciadas em 1964, é que as bolsas de valores apresentam as características atuais.

No cenário nacional, a BOVESPA, fundada em 23 de agosto de 1890, apresenta-se não apenas como o principal centro financeiro e de negócios do Brasil, mas também da América Latina.

4.1.2 Home broker

Umas das iniciativas da Bolsa de Valores de São Paulo para o desenvolvimento da negociação com as ações foi a criação do Home Broker. Através do Home Broker a Bovespa trouxe para o ambiente do pregão todas as facilidades criadas pela Internet. Os investidores podem operar eletronicamente enviando ordens de compra e venda de ações através da Internet. Para utilizar o sistema, o investidor precisa ser cliente de uma corretora membro da Bovespa que possua o sistema Home Broker (CAVALCANTE, MISUMI & RUDGE, 2005).

4.2 Análise Técnica

A análise técnica assume que os preços das ações apresentam tendência de movimento condicionada a uma dependência significativa dos preços observados no passado (CASTRO, 1979). Baseada na hipótese de que "a história se repete" (OLIVEIRA, 1986), essa abordagem procura explicar as oscilações dos preços dos títulos pela própria

evolução desses preços no mercado, realizando previsões sobre o comportamento futuro da precificação das ações (LEVY, 1969) (SÁ, 1987).

Segundo os defensores da escola técnica, a oscilação nos preços é determinada pela interpretação dada pela massa de investidores a fatores fundamentais que, a princípio, influenciam a variação dos preços das ações e que se modificam constantemente (SÁ, 1987). Para interpretar o desempenho das ações e do mercado, a análise técnica utiliza artifícios gráficos de forma a ilustrar a série histórica de preços, permitindo a identificação de tendências e formações na cotação das ações, traduzindo o comportamento do mercado e avaliando a participação de massas de investidores na indução dessas oscilações (RUDGE & CAVALCANTE, 1993).

Para CASTRO (1979), através da análise das tendências observadas nos gráficos é possível estabelecer oportunidades mais precisas de negociação. As formações, sinais gráficos decorrentes de oscilações nos preços das ações, são utilizadas como instrumentos de previsão das cotações pela constatação empírica de que após o aparecimento dessas, normalmente, os preços apresentam comportamento evolutivo idêntico ao observado.

A análise técnica assume que "as ações são avaliadas de acordo com os caprichos do mercado e não de acordo com qualquer valor resultante da rentabilidade potencial e de risco da empresa" (VANHORNE, 1972). A sua preocupação está centrada na busca de características consideradas recorrentes no tempo, sobre as quais define probabilidades de ocorrência no futuro, associando níveis de incerteza à realização da previsão (CASTRO, 1979).

4.3 Teoria de Dow

No começo do século passado, Charles Dow observou o comportamento da massa, atraída para o mercado de investimentos, e o processo de divulgação de informações sobre o mercado, para construir sua famosa Teoria de Dow, de prognósticos de tendências de preços com base em formações gráficas de preços e volumes passados. A Teoria Dow original vinculava uma tendência de mercado, desde que confirmada por movimento de preços semelhantes nas médias Dow Jones (Industrial e de Transportes) que ele próprio calculava e divulgava (CAVALCANTE & MISUMI, 2005).

Dow dizia que “o que acontece ontem pode determinar o que acontecerá hoje, e a configuração gráfica dos preços tende a se relacionar com a direção que eles tomarão no futuro”. Dow foi o primeiro a enunciar que as ações do mercado se movem juntamente, seguindo a trajetória das mais representativas, o que tornava possível medir a intensidade das oscilações através de uma média (CAVALCANTE & MISUMI, 2005).

A Teoria de Dow é composta de seis princípios básicos, a saber (NEOLOGICA, 2005):

Princípio 1: Os Índices Descontam Tudo

Os índices representam a ação conjunta de inúmeros investidores, desde os mais bem informados (que contam com as melhores informações e previsões) até os muito inexperientes. As variações diárias dos preços de um índice, portanto, já têm incluídas (descontadas) no seu valor os eventos que irão acontecer e que são desconhecidos pela maioria dos investidores.

Dessa forma, todo o fator que afeta a relação de oferta/demanda está refletida no preço do mercado. Entretanto, existem os eventos que são imprevisíveis e que as pessoas não têm como saber, como calamidades naturais, catástrofes como os atentados nas torres americanas, etc. Esses são os chamados "atos divinos”, quando acontecem podem gerar fortes oscilações iniciais, mas acabam sendo absorvidos pelo mercado.

Princípio 2: As Três Tendências do Mercado

O segundo princípio de Dow afirma que o mercado possui três tendências de movimento: primária, secundária e terciária. A tendência primária é a tendência principal de um mercado. É um movimento longo que pode ser de alta ou de baixa e que leva a uma grande valorização ou desvalorização dos ativos. Não existem regras matemáticas exatas para definir o tempo de duração das tendências, entretanto, as tendências primárias duram aproximadamente de 1 a 2 anos.

Figura 7: Exemplo de uma Tendência Primária

Uma tendência primária não se movimenta em linha reta. Ao observarmos o mercado (como no gráfico acima) percebermos que o movimento acontece como um ziguezague. Em um mercado de alta, após um impulso para cima que forma um novo topo (mais alto que o anterior), temos uma correção que forma um novo fundo (também mais alto que o fundo anterior). Em uma tendência de baixa o oposto acontece, após uma queda que forma um fundo mais baixo, acontece uma reação que cria um topo mais baixo. O conjunto desses impulsos e correções dentro de uma tendência primária são as chamadas tendências secundárias. Uma tendência secundária dura de 3 semanas a alguns meses e pode corrigir até dois terços da tendência primária que ela faz parte.

As tendências terciárias fazem parte das secundárias. São movimentos menores de, em média, até 3 semanas. Elas se comportam em relação às tendências secundárias da mesma maneira que as secundárias em relação às primárias.

Quando estamos analisando o mercado é interessante classificar as tendências do movimento atual, assim, podemos avaliar melhor as ações a serem tomadas dentro de nossa estratégia operacional.

Princípio 3: As Três Fases dos Movimentos

Dow fez uma série de observações sobre os movimentos de preços, tanto de alta como de baixa, caracterizando aspectos psicológicos marcantes de cada fase:

Fases do Mercado de Alta

- Fase 1: No início da alta o mercado começa a ser propulsionado por investidores mais qualificados, que percebem logo que novos ventos estão soprando. Enquanto isso, a maioria ainda acredita que o pior ainda está por vir, o que permite aos investidores de elite comprarem papéis muito baratos. As notícias apresentadas pela mídia refletem as expectativas negativas da maioria.
- Fase 2: A segunda parte é uma aceleração mais acentuada do movimento. A pressão compradora aumenta bastante.
- Fase 3: A terceira fase é marcada por grandes altas. Os participantes do mercado, de maneira geral, estão cada vez mais seguros de seus lucros e os investidores mais bem preparados começam a vender suas posições. A grande massa de investidores está em clima de euforia que se realimenta diariamente nos noticiários. Está aberta a possibilidade para a fase 1 do mercado de baixa.

Fases do Mercado de Baixa

- Fase 1: Nesta fase os profissionais e investidores de elite vendem seus ativos, iniciando a retração.
- Fase 2: É uma etapa marcada por um grande nervosismo, os investidores percebem o equívoco e tentam se desfazer de suas posições.
- Fase 3: Com as grandes perdas e ativos muito desvalorizados a pressão vendedora se dissipa, oportunidades para uma nova alta começam a surgir.

Princípio 4: O Princípio da Confirmação

O princípio da confirmação afirma que para uma reversão de tendência ou rompimento de nível de suporte/resistência ser válido, o fato deve ocorrer em dois índices de composições distintas. Assim, um índice confirma o outro, demonstrando que não se trata de uma oscilação temporária do movimento.

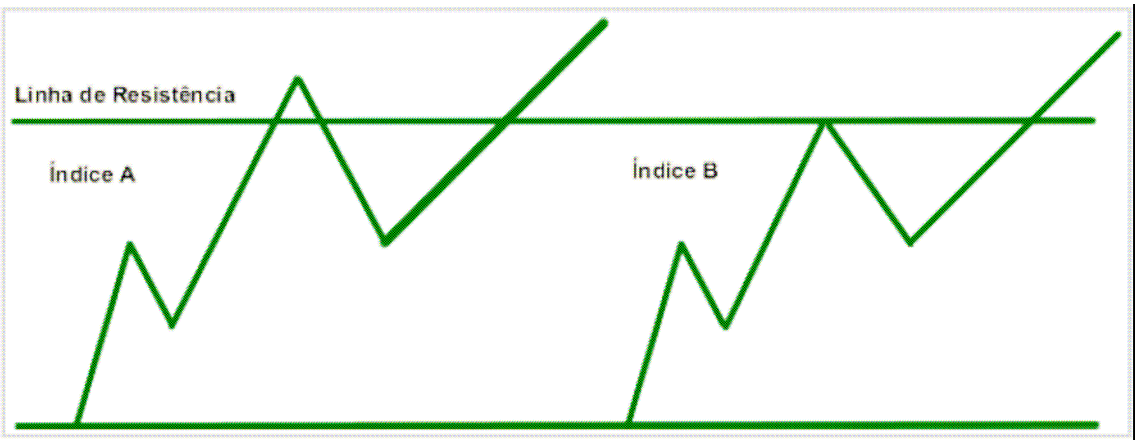

Figura 8: Gráfico exemplo do Princípio da Confirmação

Para ilustrar o princípio da confirmação suponha dois índices (A e B) de composições diferentes, mas que se comportam de maneira semelhante. O índice A, durante uma alta, vence a zona de pressão vendedora (a linha de resistência) e parece seguir com força em sua tendência. O índice B, entretanto, ao chegar pela primeira vez na linha de resistência não consegue o rompimento da mesma forma que A. Um investidor que analisa o mercado apenas a partir do ponto de vista do índice A pode concluir que existem boas oportunidades de compra, logo após o rompimento. Contudo, o que acontece é uma retração, pois o mercado não estava tão forte como demonstrou a falha de rompimento por parte de B.

Essa é a essência do princípio da confirmação. Dois índices são usados para que um pronuncie uma "segunda opinião" sobre o outro, de modo a validar o que está acontecendo ou indicar uma armadilha. No caso brasileiro, esses dois índices poderiam ser, por exemplo, o índice Bovespa e o IBRX.

Princípio 5: Volume Deve Confirmar a Tendência

Este princípio é bastante simples, na teoria de Dow o volume está relacionado com as tendências da seguinte maneira:

- **Tendência de Alta**: Em uma tendência principal de alta é esperado que o volume aumente com a valorização dos ativos e diminua nas reações de desvalorização.

- **Tendência de Baixa**: Em uma tendência principal de baixa é esperado que o volume aumente com a desvalorização dos ativos e diminua nas reações de valorização.

Princípio 6: A Tendência Continua Até Surgir um Sinal Definitivo de que Houve Reversão

Embora pareça óbvio este princípio é importante. O mercado não vai cair apenas porque atingiu um nível "alto demais" ou subir porque "já caiu demais". Uma das técnicas mais simples utilizadas é a identificação de falhas ao formar um topo mais alto (em uma tendência de alta) ou um fundo mais baixo (em uma tendência de baixa). O investidor deve possuir uma metodologia de identificação de pontos de entrada e saída, existe uma série de ferramentas de análise técnica que ajudam nessas decisões.

4.4 Médias Móveis

No mercado financeiro, principalmente no contexto da análise técnica, uma das mais populares ferramentas de análise estatísticas usando séries temporais é o cálculo de médias móveis (WIKIPEDIA, 2006). Esse método considera como previsão para o período futuro a média das observações passadas recentes (WHEELWRIGTH & MAKRIDAKS, 1985).

Existe 2 tipos principais de médias móveis: aritmética e exponencial (WIKIPEDIA, 2006), sendo que, neste trabalho será usada a média móvel aritmética devido a sua facilidade de implementação. Em MORETTIN & TOLOI (1981), a média móvel aritmética para o período de tempo t é definida por:

$$x_t = \frac{x_{t-1} + x_{t-2} + \ldots + x_{t-n}}{n}$$

onde *n* representa o número de observações incluídas na média x_t.

O termo média móvel é utilizado porque à medida que a próxima observação se torna disponível, a média das observações é recalculada, incluindo essa observação no conjunto de observações e desprezando a observação mais antiga (MORETTIN & TOLOI, 1981).

WHEELWRIGTH & MAKRIDAKS (1985) coloca que quanto maior o número de observações incluídas na média móvel, mais suave é o desenho da linha de média móvel, sendo que quanto mais curto o período de observação, mais ruidoso será este desenho.

No mercado de ações, a média móvel é uma representação da co-evolução do preço, sumarizando informações de como o preço se comportou em um determinado período passado (WIKIPEDIA, 2006).

Um exemplo muito comum de sua utilização é a combinação de médias móveis com preços para identificar qual o ponto de entrada e saída do mercado (NORONHA, 2003). A utilização do indicador auxilia o investidor a identificar se o papel está entrando em uma tendência de alta ou de baixa, provendo subsídios para sua tomada de decisão. Na Figura 7, observa-se o comportamento do papel TNLP4 em relação a média móvel de 20 dias:

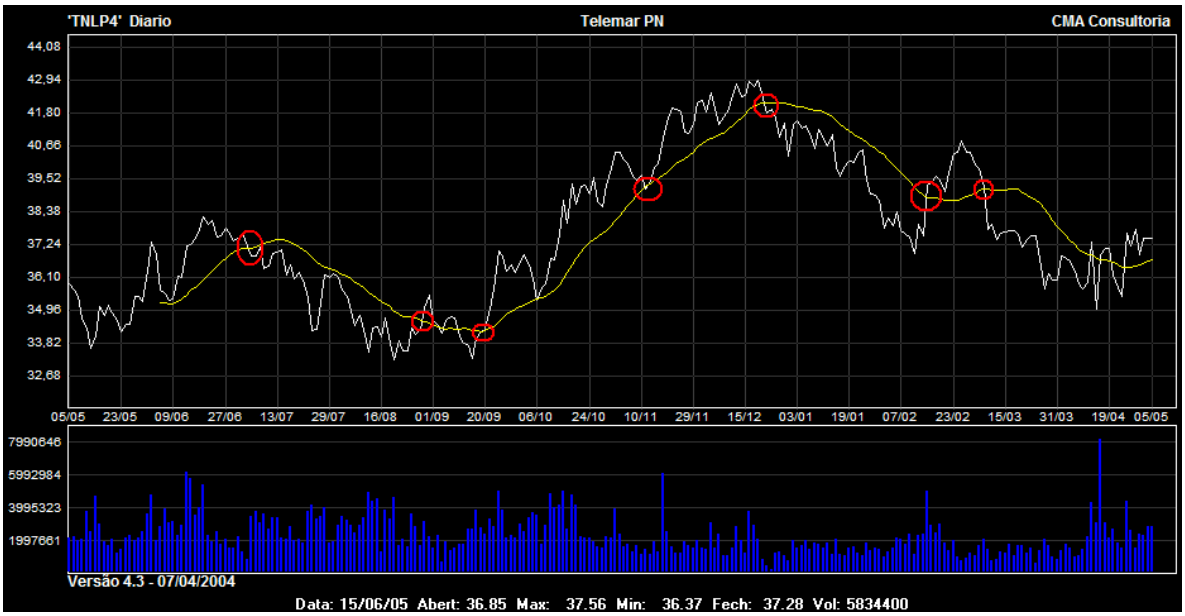

Figura 9: Exemplo de uma Média Móvel de 20 dias

5 Primeira iteração

Os dados utilizados na realização do trabalho foram da empresa Telemar, representada pelo código TNLP4 na Bovespa, a partir do dia 01/01/1999. Os dados foram tratados de forma que apenas sejam filtrados os registros do momento dos rompimentos da MM (Média Móvel) de 20 dias, tanto para cima (representando tendência de alta) quanto para

baixo (representando tendência de baixo), gerando 212 registros, dos quais 169 foram usados para treinar a rede e 43 registros, mais recentes, para testes. A figura abaixo exemplifica quando o registro é isolado para ser treinado pela rede:

Figura 10: MM de 20 dias rompida pela cotação do papel

Foram passados dados relevantes para a rede ser treinada, entretanto, por enquanto, não foi tomado nenhum embasamento nos conceitos da Teoria de Dow. A seguir, temos a listagem de atributos usados para treinar a rede:

Nome	Tipo	Descrição
Dia	Número Inteiro	Dia do rompimento da MM de 20 dias
Mês	Número Inteiro	Mês do rompimento da MM de 20 dias
Ano	Número Inteiro	Ano do rompimento da MM de 20 dias
Fechamento Anterior	Número com 2 casas decimais	Cotação do papel no fechamento do dia anterior
MM de 20 dias	Número com 2 casas decimais	Valor da média móvel de 20 dias do papel
Fechamento Atual	Número com 2 casas decimais	Cotação do papel no fechamento do dia atual
Máxima Atual	Número com 2 casas decimais	Cotação máxima do papel do dia atual
Mínima Atual	Número com 2 casas decimais	Cotação mínima do papel

		do dia atual
Tendência	Booleano	Tendência é de alta (true) ou de baixa (false)

Como saída da rede, foi questionada a validade da tendência (verdadeira ou falsa). A Figura a seguir mostrará um exemplo dos dados utilizados na rede no programa EasyNN:

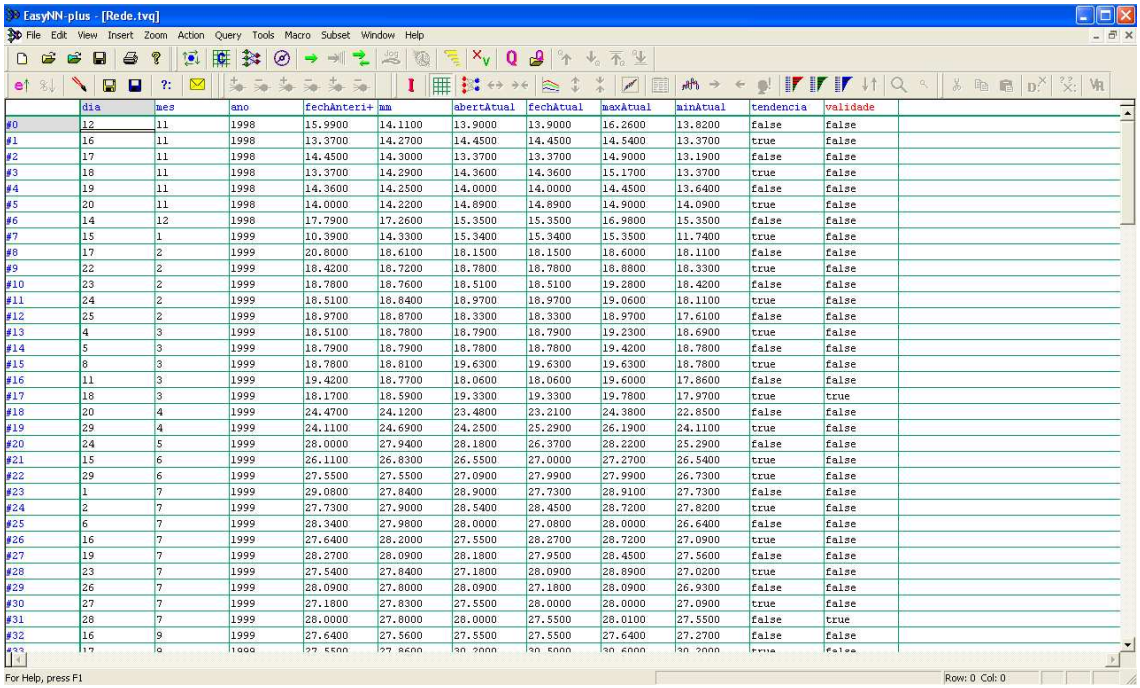

	dia	mes	ano	fechAnteri+	mm	abertAtual	fechAtual	maxAtual	minAtual	tendencia	validade
#0	12	11	1998	15.9900	14.1100	13.9000	13.9000	16.2600	13.8200	false	false
#1	16	11	1998	13.3700	14.2700	14.4500	14.4500	14.5400	13.3700	true	false
#2	17	11	1998	14.4500	14.3000	13.3700	13.3700	14.9000	13.1900	false	false
#3	18	11	1998	13.3700	14.2900	14.3600	14.3600	15.1700	13.3700	true	false
#4	19	11	1998	14.3600	14.2500	14.0000	14.0000	14.4500	13.6400	false	false
#5	20	11	1998	14.0000	14.2200	14.8900	14.8900	14.9000	14.0900	true	false
#6	14	12	1998	17.7900	17.2600	15.3500	15.3500	16.9800	15.3500	false	false
#7	15	1	1999	10.3900	14.3300	15.3400	15.3400	15.3500	11.7400	true	false
#8	17	2	1999	20.8000	18.6100	18.1500	18.1500	18.6000	18.1100	false	false
#9	22	2	1999	18.4200	18.7200	18.7800	18.7800	18.8800	18.3300	true	false
#10	23	2	1999	18.7800	18.7600	18.5100	18.5100	19.2800	18.4200	false	false
#11	24	2	1999	18.5100	18.8400	18.9700	18.9700	19.0600	18.1100	true	false
#12	25	2	1999	18.9700	18.8700	18.3300	18.3300	18.9700	17.6100	false	false
#13	4	3	1999	18.5100	18.7800	18.7900	18.7900	19.2300	18.6900	true	false
#14	5	3	1999	18.7900	18.7900	18.7800	18.7800	19.4200	18.7800	false	false
#15	8	3	1999	18.7800	18.8100	19.6300	19.6300	19.6300	18.7800	true	false
#16	11	3	1999	19.4200	18.7700	18.0600	18.0600	19.6000	17.8600	false	false
#17	18	3	1999	18.1700	18.5900	19.3300	19.3300	19.7800	17.9700	true	true
#18	20	4	1999	24.4700	24.1200	23.4800	23.2100	24.3800	22.8500	false	false
#19	29	4	1999	24.1100	24.6900	24.2500	25.2900	26.1900	24.1100	true	false
#20	24	5	1999	28.0000	27.9400	28.1800	26.3700	28.2200	25.2900	false	false
#21	15	6	1999	26.1100	26.8300	26.5500	27.0000	27.2700	26.5400	true	false
#22	29	6	1999	27.5500	27.5500	27.0900	27.9900	27.9900	26.7300	true	false
#23	1	7	1999	29.0800	27.8400	28.9000	27.7300	28.9100	27.7300	false	false
#24	2	7	1999	27.7300	27.9000	28.5400	28.4500	28.7200	27.8200	true	false
#25	6	7	1999	28.3400	27.9800	28.0000	27.0800	28.0000	26.6400	false	false
#26	16	7	1999	27.6400	28.2000	27.5500	28.2700	28.7200	27.0900	true	false
#27	19	7	1999	28.2700	28.0900	28.1800	27.9500	28.4500	27.5600	false	false
#28	23	7	1999	27.5400	27.8400	27.1800	28.0900	28.8900	27.0200	true	false
#29	26	7	1999	28.0900	27.8000	28.0900	27.1800	28.0900	26.9300	false	false
#30	27	7	1999	27.1800	27.8300	27.5500	28.0000	28.0000	27.0900	true	false
#31	28	7	1999	28.0000	27.8000	28.0000	27.5500	28.0100	27.5500	false	true
#32	16	9	1999	27.6400	27.5600	27.5500	27.5500	27.6400	27.2700	false	false

Figura 11: Dados utilizados no software EasyNN

A montagem e treinamento da rede foi feito usando as configurações padrões do programa, construindo uma rede com 6 neurônios na camada escondida, como podemos observar na Figura 12:

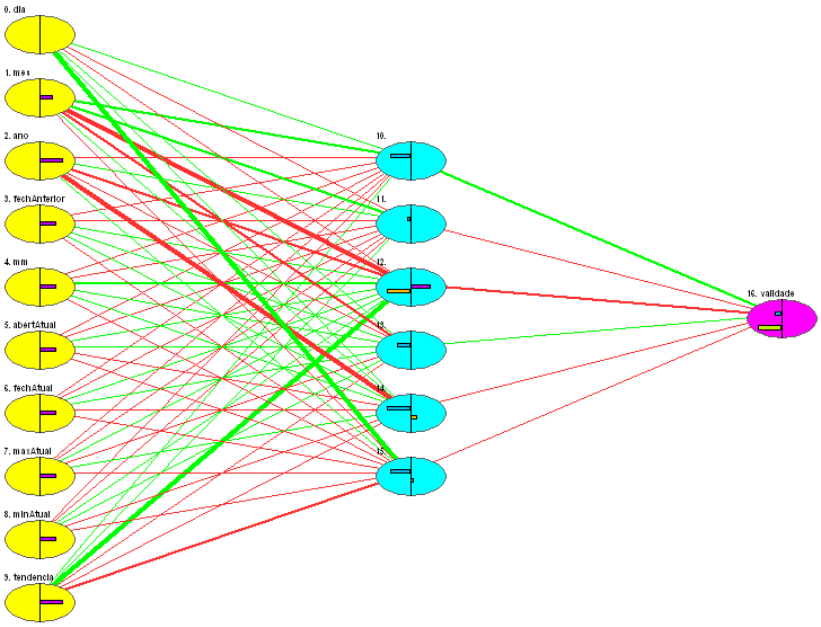

Figura 12: Rede projetada pelo programa EasyNN

O treinamento da rede foi desenvolvido usando o artifício do programa de guardar suas configurações que alcançaram um melhor acerto médio, ou seja, a rede que teve o erro médio menor, conforme é evidenciado através das seguintes figuras:

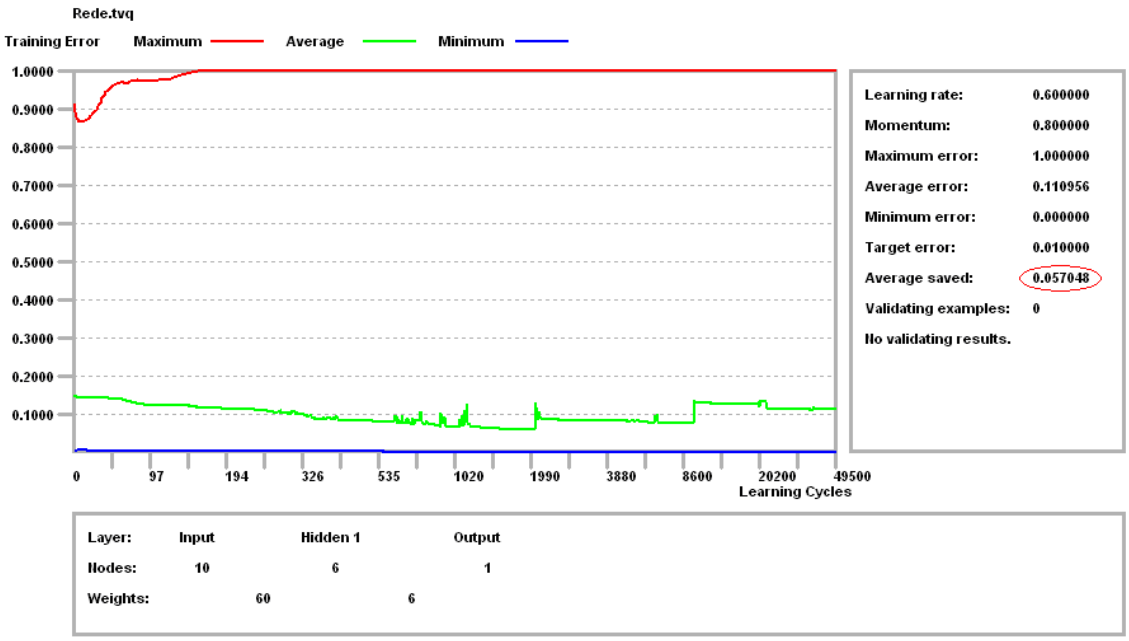

Figura 13: Gráfico de desempenho da rede

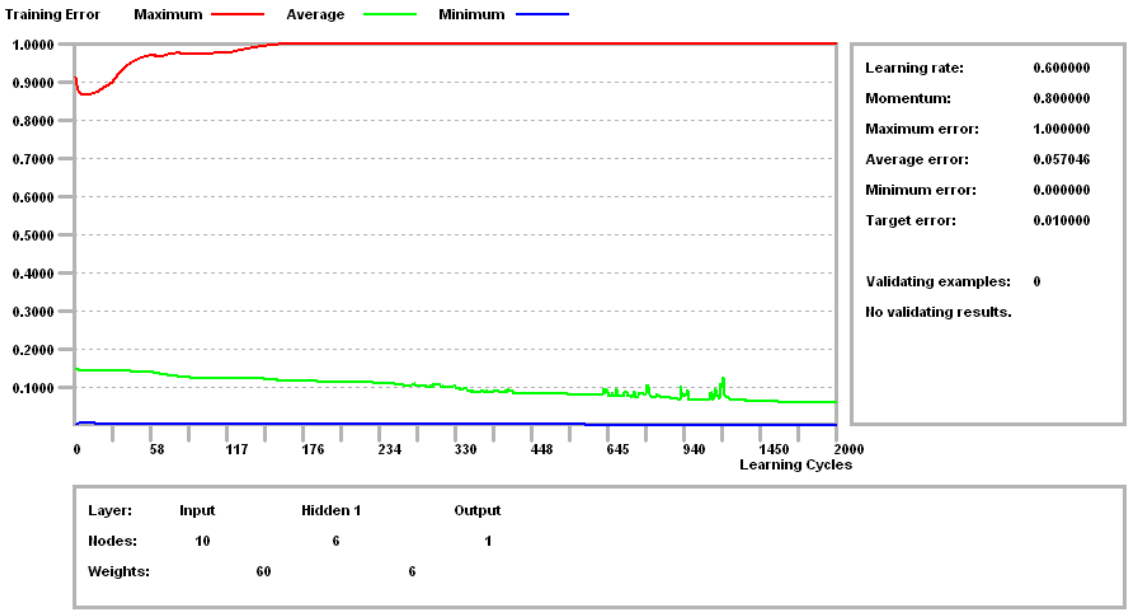

Figura 14: Gráfico de desempenho da rede com o melhor aprendizado

Após o treinamento da rede, foram investigados os motivos do alto índice no erro máximo, e, foi detectado que determinados registros não puderam ser generalizados pela rede, gerando sempre uma saída insatisfatória.

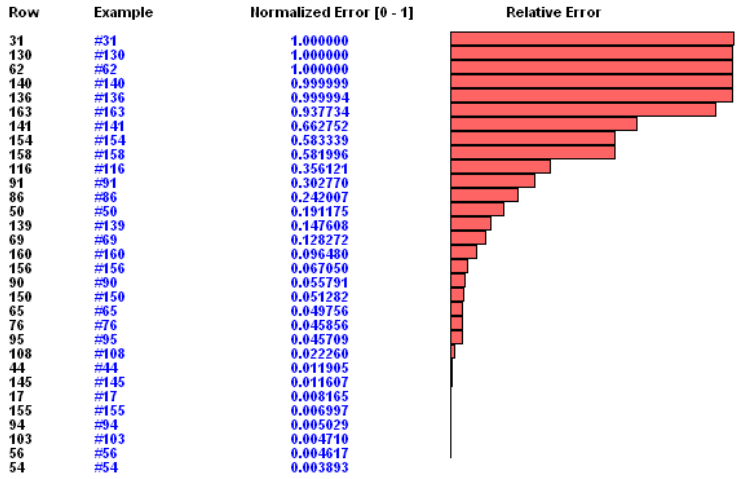

Row	Example	Normalized Error [0 - 1]
31	#31	1.000000
130	#130	1.000000
62	#62	1.000000
140	#140	0.999999
136	#136	0.999994
163	#163	0.937734
141	#141	0.662752
154	#154	0.583339
158	#158	0.581996
116	#116	0.356121
91	#91	0.302770
86	#86	0.242007
50	#50	0.191175
139	#139	0.147608
69	#69	0.128272
160	#160	0.096480
156	#156	0.067050
90	#90	0.055791
150	#150	0.051282
65	#65	0.049756
76	#76	0.045856
95	#95	0.045709
108	#108	0.022260
44	#44	0.011905
145	#145	0.011607
17	#17	0.008165
155	#155	0.006997
94	#94	0.005029
103	#103	0.004710
56	#56	0.004617
54	#54	0.003893

Figura 15: Registros que não conseguiam ser generalizados pela rede

Depois da rede treinada, foram aplicados testes para verificar a sua eficiência na generalização dos fatores que determinavam a validade da tendência, conforme demonstrados na tabela a seguir:

	Quantidade	(%)
Acertos	22	51.16%
Erros	21	48.84%

TOTAL de Registros 43 100%

6 Segunda iteração

Seguindo a mesma estratégia da primeira iteração, foram selecionados apenas os registros que continham o rompimento da média móvel de 20 dias, sendo acrescido outros dados, levando em conta aspectos da Teoria de Dow. A seleção dos dados seguindo esses critérios leva em conta o segundo principio da Teoria de Dow, somente validando tendências que continuam na mesma direção por mais de 20 pregões, ou seja, uma tendência terciária. O objetivo de identificar apenas as tendências válidas, também atendem ao terceiro princípio, que é verificar se o mercado está em uma fase de alta ou de baixa, conforme nossos parâmetros. Para confirmar o movimento do mercado, foram colocadas médias móveis referentes a um índice auxiliar, no caso *in croncreto,* o Ibovespa, seguindo o quarto princípio. Para atender ao quinto princípio da teoria, foram informados também o volume de negócios do papel estudado, o que servirá para demonstrar a força que o movimento possui.

Sendo assim, temos a seguinte listagem de atributos utilizados como entrada da rede:

Nome	Tipo	Descrição
Dia	Número Inteiro	Dia do rompimento da MM de 20 dias
Mês	Número Inteiro	Mês do rompimento da MM de 20 dias
Ano	Número Inteiro	Ano do rompimento da MM de 20 dias
MM de 5 dias do papel	Número com 2 casas decimais	Valor da média móvel de 5 dias do papel
MM de 10 dias do papel	Número com 2 casas decimais	Valor da média móvel de 10 dias do papel
MM de 20 dias do papel	Número com 2 casas decimais	Valor da média móvel de 20 dias do papel
MM de 5 dias do índice auxiliar	Número com 2 casas decimais	Valor da média móvel de 5 dias do índice auxiliar
MM de 10 dias do índice auxiliar	Número com 2 casas decimais	Valor da média móvel de 10 dias do índice auxiliar

MM de 20 dias do índice auxiliar	Número com 2 casas decimais	Valor da média móvel de 20 dias do índice auxiliar
Fechamento Anterior do papel	Número com 2 casas decimais	Cotação do papel no fechamento do dia anterior
Fechamento Atual do papel	Número com 2 casas decimais	Cotação do índice auxiliar no fechamento do dia atual
Fechamento Anterior do índice auxiliar	Número com 2 casas decimais	Cotação do índice auxiliar fechamento do dia anterior
Fechamento Atual do índice auxiliar	Número com 2 casas decimais	Cotação do papel no fechamento do dia atual
Máxima Atual	Número com 2 casas decimais	Cotação máxima do papel do dia atual
Mínima Atual	Número com 2 casas decimais	Cotação mínima do papel do dia atual
Tendência	Booleano	Tendência é de alta (true) ou de baixa (false)

Seguindo o mesmo objetivo da primeira rede, foi questionada à rede neural a validade da tendência (se verdadeira ou falsa). A Figura 14 mostra um exemplo dos dados usados para treinar a rede:

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P
1	dia	mes	ano	fechAnterior	fechAtual	mm0	mm1	mm2	mmAux0	mmAux1	mmAux2	fechAnteriorAux	fechAtualAux	volume	tendencia	validade
2	12	11	1998	15.99	13.9	15.88	14.78	14.11	7937.6	7652.9	7340.9	7762	7470	10723870	0	0
3	16	11	1998	13.37	14.45	14.9	14.94	14.27	7770	7856.2	7442.75	7615	8003	8350110	1	0
4	17	11	1998	14.45	13.37	14.22	14.88	14.3	7836	7938.3	7517.05	8003	8330	13436330	0	0
5	18	11	1998	13.37	14.36	13.89	14.94	14.29	7993	8027.5	7595.75	8330	8547	13392730	1	0
6	19	11	1998	14.36	14	13.91	14.89	14.25	8162.4	8050	7644.1	8547	8317	7992060	0	0
7	20	11	1998	14	14.89	14.21	14.76	14.22	8345.6	8081.7	7690.5	8317	8531	6252140	1	0
8	14	12	1998	17.79	15.35	18.19	18.53	17.26	7301.8	7677.8	8166.5	7195	6583	4545750	0	0
9	15	1	1999	10.39	15.34	12.49	13.5	14.28	5947.6	6485.4	6659.45	5057	6746	9667140	1	0
10	17	2	1999	20.8	18.15	19.35	19.08	18.4	8888.8	8782.9	8137.1	8952	8974	2795130	0	0
11	22	2	1999	18.42	18.78	18.84	18.92	18.66	8974.6	8847.8	8422.5	9013	9074	1658010	1	0
12	23	2	1999	18.78	18.51	18.38	18.86	18.67	8972.6	8876.8	8485.9	9074	8942	9215840	0	0
13	24	2	1999	18.51	18.97	18.55	18.95	18.73	8968.4	8928.6	8567.5	8942	8953	2545560	1	0
14	25	2	1999	18.97	18.33	18.6	18.8	18.78	8931.2	8928.5	8641.75	8953	8674	4314880	0	0
15	4	3	1999	18.51	18.79	18.48	18.54	18.73	9168	9049.6	8914.7	9154	9508	9147700	1	0
16	8	3	1999	18.78	19.63	18.79	18.66	18.79	9396.4	9165.9	9006.85	9465	9785	5256110	1	0
17	12	3	1999	19.42	17.34	18.86	18.67	18.73	9617.2	9392.6	9160.55	9778	9574	5859100	0	0
18	18	3	1999	18.17	19.33	18.28	18.72	18.59	10434.6	10019.3	9502.05	10634	10894	11937120	1	1
19	20	4	1999	24.47	23.21	24.33	25.08	24.12	11232.6	11313.1	11054.05	11196	10989	12469110	0	0
20	29	4	1999	24.11	25.29	24.18	24.19	24.69	10985	11086.6	11152.4	11127	11085	6501110	1	0
21	24	5	1999	28	26.37	28.39	29.15	27.94	11870.8	12071.3	11798.75	11727	11154	8047700	0	0
22	15	6	1999	26.11	27	26.27	26.35	26.83	11069.8	11070.7	11243.1	11084	11183	3045380	1	0
23	29	6	1999	27.55	27.99	27.94	28.76	27.55	11416.8	11621.1	11345.9	11264	11379	6123660	1	0
24	1	7	1999	29.08	27.73	28.07	28.57	27.84	11439.2	11627.4	11410.3	11626	11708	8968480	0	0
25	2	7	1999	27.73	28.45	28.16	28.4	27.9	11562.4	11623.2	11440.4	11708	11835	5642630	1	0
26	6	7	1999	28.34	27.08	28.14	28.04	27.98	11755.8	11586.3	11516.95	11936	11674	3500320	0	0
27	16	7	1999	27.64	28.27	27.77	27.83	28.2	11338.4	11539.1	11583.25	11361	11407	6686150	1	0
28	19	7	1999	28.27	27.95	27.88	27.78	28.09	11374	11500.7	11561.95	11407	11451	7705340	0	0
29	23	7	1999	27.54	28.09	27.64	27.71	27.84	11250.8	11294.6	11442.05	11238	10989	9222820	1	0

Figura 16: Exemplo da massa de dados usados no treinamento da rede

Seguindo a mesma estratégia da iteração anterior, a rede foi montada usando configurações padrões do programa, que colocou 15 neurônios na camada de entrada, 11

neurônios na camada oculta e um neurônio na camada de saída. Abaixo está a Figura 15 mostrando a rede após o treinamento.

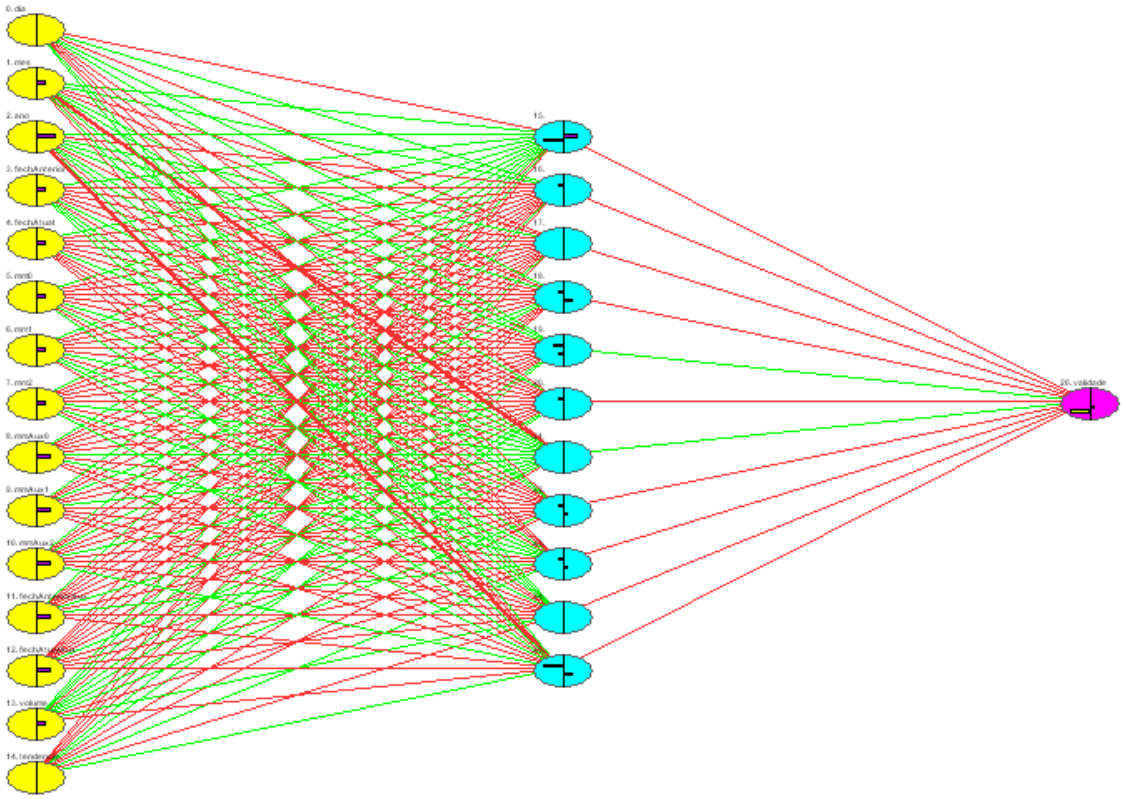

Figura 17: Rede após o treinamento

A convergência do treinamento nessa iteração foi mais bem sucedido do que a anterior, mas ainda apresentava determinados registros em que a rede não conseguia generalizar.

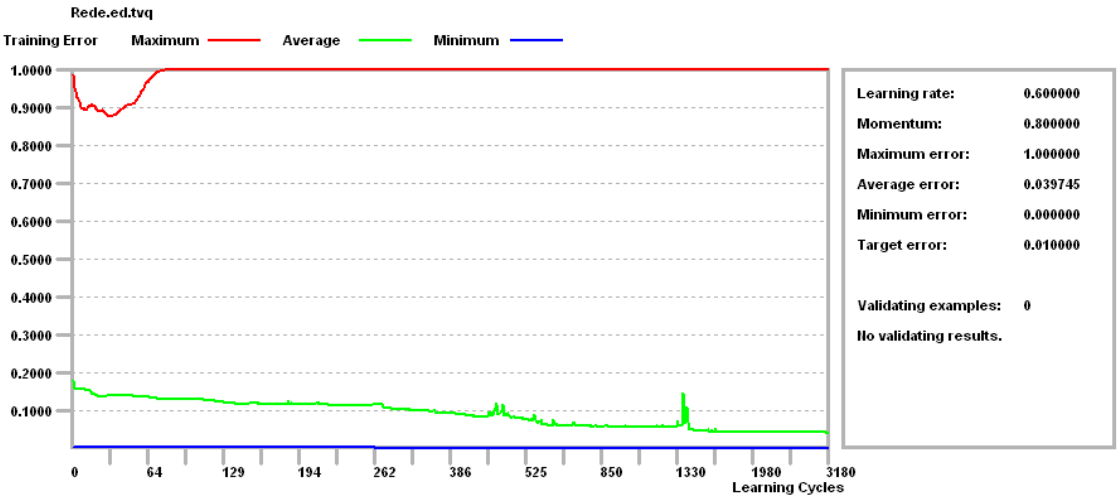

Figura 18: Gráfico do desempenho de aprendizagem da rede

Um aspecto interessante notado nesse treinamento foi a sensibilidade dada a alguns dados incluídos nessa iteração, como pode ser visto na Figura 19:

Column	Input Name	Change from	to	Sensitivity	Relative Sensitivity
12	fechAtualAux	6583	22673	0.999834196	
11	fechAnteriorAux	5057	23851	0.999685861	
10	mmAux2	6659.4500	23490.3000	0.999043537	
8	mmAux0	5947.6000	23656.6000	0.981705338	
9	mmAux1	6485.4000	23476.9000	0.948391372	
4	fechAtual	13.3700	48.0000	0.945078625	
6	mm1	13.5000	49.5500	0.583220812	
2	ano	1998	2004	0.493869488	
13	volume	1555020	252582592	0.285685468	
1	mes	1	12	0.149817787	
3	fechAnterior	10.3900	50.8300	0.050658479	
14	tendencia	false	true	0.042660179	
0	dia	1	31	0.019553337	
5	mm0	12.4900	50.5200	0.009965601	
7	mm2	14.1100	48.4600	0.005587627	

Figura 19: Lista com as entradas com maior sensibilidade na rede

Com a rede treinada, foram aplicados testes com registros não incluídos no treinamento, e obteve-se uma pequena melhora.

	Quantidade	(%)
Acertos	23	54,76%
Erros	19	45.24%
TOTAL	42	100%

7 Terceira iteração

Na terceira iteração foram utilizados os dados da segunda, passados por uma validação simples, selecionando apenas os registros que não eram categorizados como repiques ou oscilações momentâneas do preço, gerando, desta forma, sinais de registros falsos para a rede.

Na Figura 20 é demonstrado um movimento de alta que ocorreu no ponto 1 e um repique no ponto 2, que poderiam gerar uma falsa invalidação da tendência e o início de uma tendência contrária.

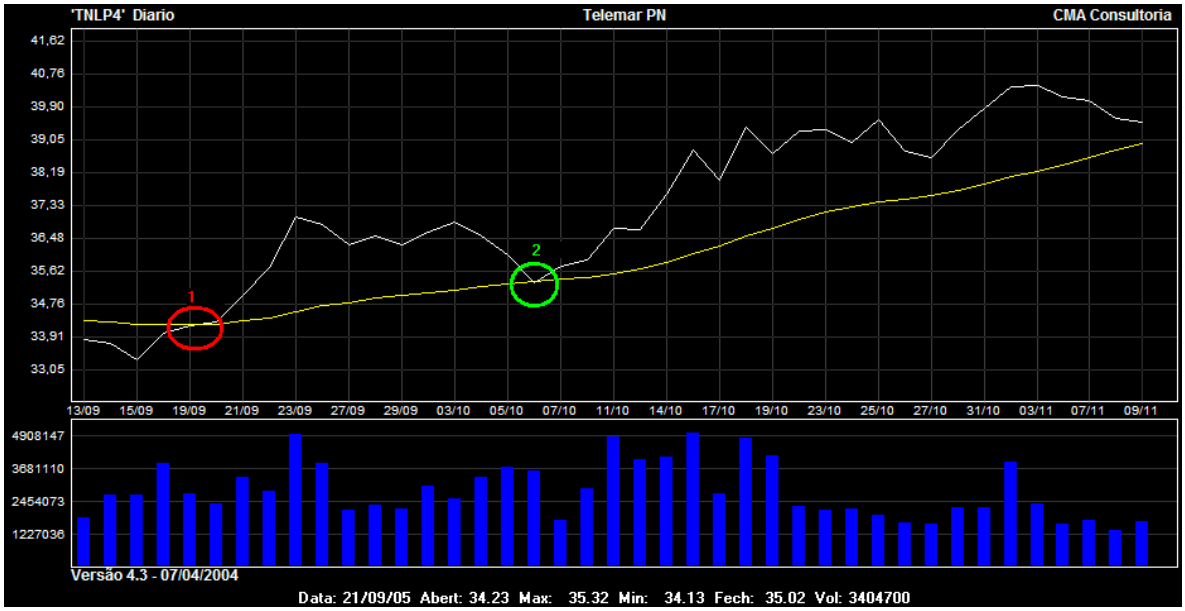

Figura 20: Exemplo de uma falsa invalidação da tendência

Sendo assim, foi definido um critério para incluir o registro no treinamento da rede, sendo que, o rompimento da média móvel deve ter a duração mínima de 2 dias, o que diminuiu a quantidade total de registros para 86, e aumentou a proporção de registros válidos para 43 (50%).

Foram usadas as mesmas entradas e saídas da iteração anterior, mas foram colocados apenas 8 neurônios na camada oculta da rede, conforme pode ser visto na Figura 21:

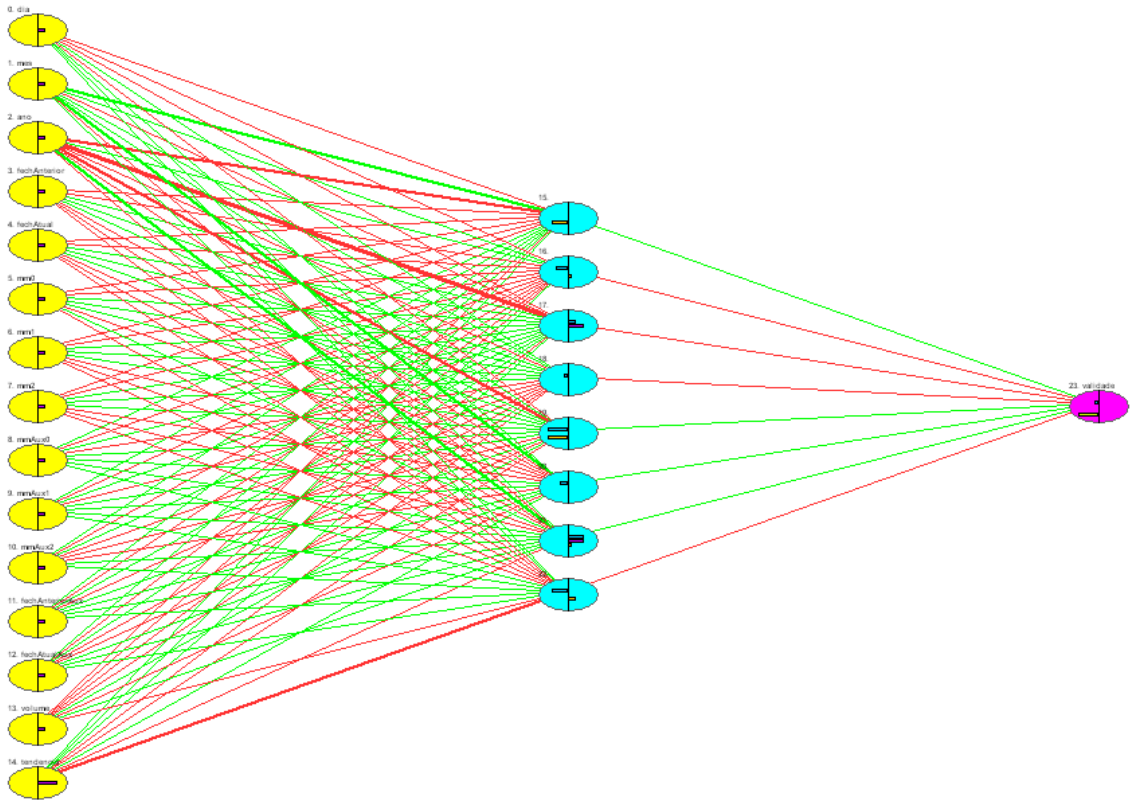

Figura 21: Desenho gerado para a rede da 3 iteração

Esta última rede teve uma convergência melhor do que as iterações anteriores, mas ainda continuava apresentando problemas quanto ao erro máximo.

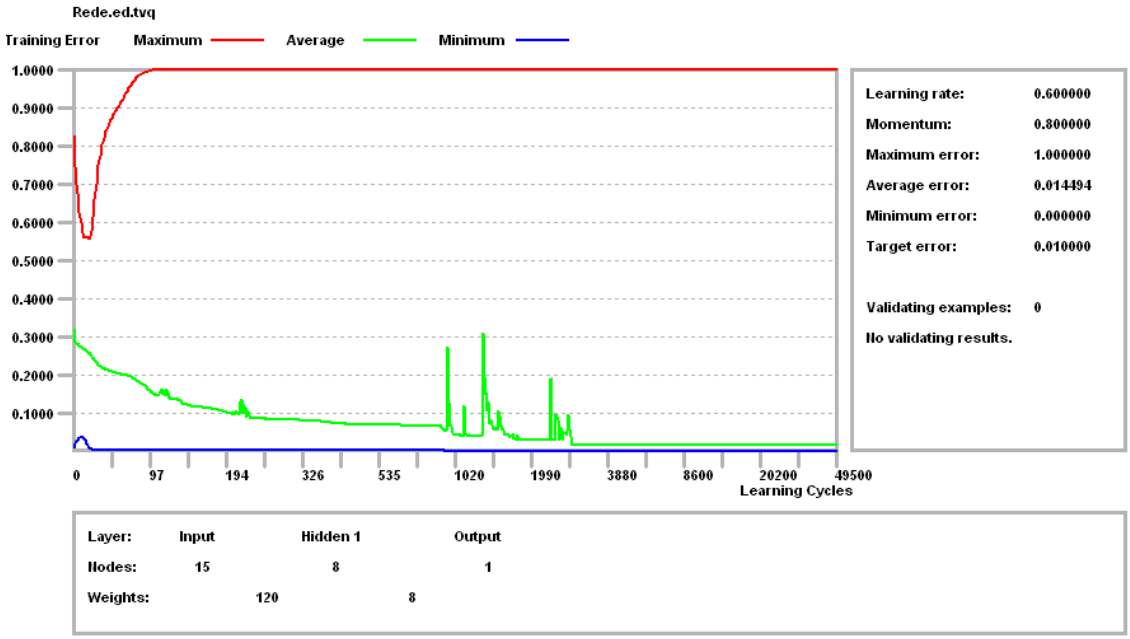

Figura 22: Aprendizagem da rede na 3ª iteração

Foi constatado também apenas um registro que não estava sendo generalizado pela rede, sendo que todos os outros registros de treinamento conseguiam se encaixar nos padrões encontrados com erros mínimos.

Rede.ed.tvq cycle 50000. Target error 0.0100 Average training error 0.014494

The first 69 of 69 Example rows in descending order.

Above target
Below target

Row	Example	Normalized Error [0 - 1]	Relative Error
46	#46	1.000000	
56	#56	0.000015	
53	#53	0.000012	
57	#57	0.000011	
54	#54	0.000008	
40	#40	0.000008	
23	#23	0.000007	

Figura 23: Registro que não foi generalizado pela rede

Após o treinamento da rede, foram feitos testes com registros desconhecidos pela rede, o qual apresentou uma melhora significativa em relação à primeira iteração, conforme pode ser conferido na tabela abaixo.

	Quantidade	(%)
Acertos	11	61.11%
Erros	7	38,89%
TOTAL	18	100%

8 Conclusão

Conforme o acompanhamento das três iterações, foi possível acompanhar a evolução da aprendizagem de cada rede, e, principalmente, evidenciar a melhora dos resultados conforme o enriquecimento e a seleção dos dados utilizados.

Os benefícios da utilização de aspectos da Teoria de Dow foram percebidos, mostrando-se relevante na fase de enriquecimento de dados. A seleção dos registros utilizados também foi decisiva no desempenho em cada iteração, mostrando a importância de conhecer bem o domínio e o contexto em que os dados estão contidos.

Apesar da evolução na acuidade na verificação da tendência, o modelo precisa ser melhorado para conseguir um nível de acerto mais satisfatório, permitindo sua utilização prática viável. Dentre as limitações do trabalho, pode-se observar que a ocorrência do requisito para a seleção do registro, ou seja, o cruzamento da média móvel de 20 dias pela cotação de fechamento, é um fato incomum e com pouca freqüência, limitando a ação do investidor em poucas oportunidades de investimento durante o ano.

9 Referências

CASTRO, Hélio Oliveira Portocarrero de. **Introdução ao Mercado de Capitais**. 10. ed. Rio de Janeiro : Instituto Brasileiro de Mercado de Capitais - IBMEC, 1979.

CAVALCANTE, Francisco; MISUMI, Jorge Yoshio e RUDGE, Luiz Fernando. **Mercado de Capitais: O que é, como funciona**.6ª ed. Rio de Janeiro : Elsevier, 2005.

DANDOLINI, G. A. **Um procedimento para avaliação da saúde financeira de pequenas empresas: estudo de um caso usando redes neuronais artificiais**. 1997. Dissertação (Mestrado em Engenharia de Produção) – UFSC, Florianópolis.

FALCÃO, D. M. ***Redes neurais***. Disponível em http://www.nacad.ufrj.br/~falcao/.

Acesso em 19 maio 2006.

FAUSETT, L. **Fundamentals of Neural Networks – Architecture, Algorithms, and Applications**. [S.l.]: Prentice Hall International, Inc., 1994.

FILHO, Armando Mellagi. **Mercado Financeiro e de Capitais: Uma Introdução**. 2ª ed. São Paulo : Editora Atlas S.A, 1995.

FREIMAN, José Paulo e PAMPLONA, Edson de O. **Redes Neurais Artificiais na Previsão do Valor de Commodity do Agronegócio**. V Encuentro Internacional de Finanzas. Santiago, Chile, 19 a 21 de janeiro de 2005.

HAYKIN, Simon. **Redes Neurais: Princípios e prática**. 2ª ed. Porto Alegre: Bookman, 2001.

LAWRENCE, R. **Using Neural Networks to Forecast Stock Market Prices**. Dez. 1997. Disponível em: <http://www.cs.uiowa.edu/~rlawrenc/research/Papers/nn.pdf >. Acesso em: maio 2006.

LEVY, Robert A. **The Relative Strength Concept of Common Stock Price Forecasting**. New York : Investors Intelligence Inc, 1969.

MORETTIN, Pedro Alberto; TOLOI, Clélia Maria de Castro. Modelos para Previsão de Séries Temporais. **In : 13° Colóquio Brasileiro de Matemática**. Rio de Janeiro : [s.n.], 1981.

NEOLÓGICA. A Teoria de Dow. Disponível em: http://www.neologica.com.br/tutoriais/introtec/introtec03.php Acesso em Maio 2006.

NORONHA, Márcio; Análise Técnica: Teorias Ferramentas Estratégias. 5ª Edição. EDITEC, 2003.

OLIVEIRA, Miguel Delmar de. **Introdução ao Mercado de Ações**. Rio de Janeiro : Comissão Nacional de Bolsas de Valores - CNBV, 1986.

OSÓRIO, F. ; BITTENCOURT, J. R. ***Sistemas inteligentes baseados em RNAs aplicados ao processamento de imagens***. In: Workshop de Inteligência Artificial, Santa Cruz do Sul: UNISC, 2000.

RUDGE, Luiz Fernando; CAVALCANTE, Francisco. **Mercado de Capitais**. 2. ed. Belo Horizonte : Comissão Nacional de Bolsas de Valores - CNBV, 1993.

SÁ, Geraldo Tosta de. **Mercado de Ações & Bolsas de Valores**. Rio de Janeiro : Aplicação Editora Técnica Ltda, 1987.

SATYADAS, A. ; CHEN, H. C. ***An application of intelligent neural network to time series business fluctuation prediction***. IEEE, pp. 3640-3645, 1994.

SMITH, K. A. ; GUPTA, J. N. D. ***Neural networks in business: techniques and applications for the operations researcher***. Computers & Operations Research, pp. 1023-1044, 2000.

VAN HORNE, James C. **Funções e Análise das Taxas de Mercado de Capitais**. São Paulo : Editora Atlas, 1972.

WHEELWRIGHT, Steven C.; MAKRIDAKIS, Spyros. **Forecasting Methods for Management**. 4th edition. New York : John Wiley & Sons Inc, 1985.